

PERBANDINGAN METODE MULTILEVEL THRESHOLDING DAN SEMANTIC SEGMENTATION SEGNET UNTUK DETEKSI STROKE BERDASARKAN GAMBAR CT SCAN OTAK

Arif Nur Rochman, Fajar Astuti Hermawati

Teknik Informatika. Fakultas Teknik, Universitas 17 Agustus 1945 Surabaya

Jl. Semolowaru No.45, Menur Pumpungan, Kec. Sukolilo, Surabaya

E-mail : arifblogger77@gmail.com

Abstract

Advanced computer vision techniques such as deep learning show tremendous potential for extracting clinically significant information from medical images. The main common characteristic of deep learning methods is their focus on feature learning and has recently been applied to CT imaging for acute stroke. The presence of acute hemorrhagic stroke was confirmed clinically using non-contrast computed tomography (CT) imaging. The main objective of this study is to compare the multilevel thresholding and semantic segmentation segnet methods to detect stroke from a CT scan with accurate results. The research stages of the input data will detect the lesion area, which is then segmented and classified. The input is a CT scan image using the multilevel thresholding method and image segmentation to get the results of the classification of stroke types. This study obtained an average accuracy of SVM testing of 94.48% with a precision value of 0.7760 and a dice similarity of 0.6410 for the segnet method, while for the thresholding method, a precision value of 0.8890 and a dice similarity of 0.8379 was obtained. The conclusion of this study shows that the thresholding method is better than image segmentation.

Keyword: Stroke, Multi Thresholding, CT Scan, Semantic Segmentation

Abstrak

Kemajuan teknik visi komputer seperti deep learning menunjukkan potensi luar biasa untuk mengekstraksi informasi penting secara klinis dari citra medis. Karakteristik umum utama dari metode deep learning adalah fokus pada pembelajaran fitur dan baru-baru ini diterapkan pada pencitraan CT untuk stroke akut. Stroke iskemik terjadi jika suplai darah ke beberapa bagian otak terpengaruh. Keberadaan stroke hemoragik akut dikonfirmasi secara klinis menggunakan pencitraan computed tomography (CT) non-kontras. Tujuan utama dari penelitian ini adalah melakukan perbandingan metode multilevel thresholding dan semantic segmentation segnet untuk mendeteksi stroke dari CT Scan dengan hasil yang akurat. Adapun tahapan penelitian dari input data maka akan dilakukan pendekripsi area lesi yang kemudian di segmentasikan dan dilakukan klasifikasi. Input berupa gambar CT Scan dengan menggunakan metode multilevel thresholding dan image segmentation untuk mendapatkan hasil klasifikasi jenis stroke. Penelitian ini mendapatkan hasil akurasi rata-rata pengujian SVM sebesar 94,48% dengan nilai precision sebesar 0,7760 dan dice similarity sebesar 0,6410 untuk metode segnet sedangkan untuk metode thresholding mendapatkan nilai precision sebesar 0,8890 dan dice similarity sebesar 0,8379. Kesimpulan dari penelitian ini menunjukkan bahwasanya metode thresholding lebih baik dari image segmentation.

Kata kunci: Stroke, Multi Thresholding, CT Scan, Semantic Segmentation

1 PENDAHULUAN

Kemajuan dalam teknik visi komputer, seperti deep learning telah menunjukkan potensi luar biasa untuk mengekstraksi informasi penting secara klinis dari citra medis [1]. Karakteristik umum utama dari metode deep learning adalah fokus pada pembelajaran fitur dan baru-baru ini diterapkan pada pencitraan CT untuk stroke akut [2], [3]. Dikarenakan stroke adalah penyakit yang penyebab kematian terbesar ketiga dan sumber kecacatan jangka panjang terbesar di dunia [3], [4]. Dalam mengatasi masalah tersebut penelitian ini mengajukan tentang pendekripsi stroke dari CT Scan dengan tujuan utama melakukan perbandingan metode multilevel thresholding dan semantic segmentation segnet untuk mendekripsi stroke dari CT Scan dengan hasil yang akurat.

<i>Dataset</i> terdiagnosis	36 CT Scan
Pasien laki-laki	46
Pasien Perempuan	36

Spesifikasi dataset terdiri dari 82 CT Scan dengan dataset yang terdiagnosis hemorrhage sebanyak 36 CT Scan dengan demografi pasien laki-laki sebanyak 46 dan perempuan 36 yang dapat dilihat pada Tabel 1.

2 METODE PENELITIAN

Pada bagian ini akan dijelaskan metode-metode yang digunakan pada penelitian.

2.1 Tahapan Penelitian

Pada bagian ini akan dijelaskan mengenai tahapan penelitian dari pengambilan dataset, preprocessing dataset, layer arsitektur vgg16 pada Segnet, tahapan segmentasi dan metode evaluasi segmentasi.

2.1.1 Pengambilan Dataset

Penelitian dimulai dengan memilih dataset menjadi dua, yakni citra asli dan citra *segmentation*, kemudian dilakukan *split data* yang menghasilkan folder *train* dimana isi dari folder *train*, yaitu folder *image*, dan label. Di mana masing-masing folder berisi 2500 data citra.

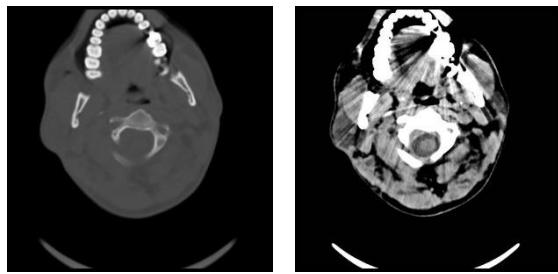
Tabel 1 Spesifikasi Dataset

Jumlah Dataset	82 CT Scan
----------------	------------

Tabel 2 Spesifikasi Gambar Dataset

Folder	Bone dan Brain
Jumlah Gambar	30 Potongan dengan ketebalan potongan 5 mm di setiap folder
Ekstensi Gambar	JPG
Pembagian Label / Kelas	<i>Hemorrhage</i> , <i>No Hemorrhage</i>
Distribusi Kelas	<i>Hemorrhage</i> : 318 <i>No Hemorrhage</i> : 2183

Spesifikasi gambar dataset pada masing-masing CT Scan terdiri dari citra Bone dan Brain seperti pada Gambar 1 dengan jumlah gambar 30 potongan dengan ketebalan 5 mm yang berekstensi JPG. Kelasnya terdiri dari *Hemorrhage* dan *No Hemorrhage* dengan distribusi untuk kelas hemorrhage sebanyak 318 dan *No hemorrhage* sebanyak 2183 citra yang dilihat pada Tabel 2.



Gambar 1 Sampel Bone (kiri) dan Brain (kanan)

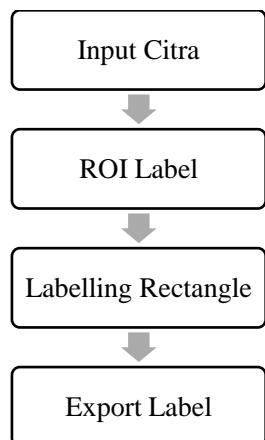
Tabel 3 Dataset yang Digunakan

Data	Jumlah Data
Semua Label Perdarahan (Hemorrhage)	316

Pada Tabel 3 penelitian ini menggunakan sebanyak 316 data dengan data jenis Hemorrhage.

2.1.2 Preprocessing Dataset

Pertama yang dilakukan adalah labelling dataset dengan menggunakan image labeller.

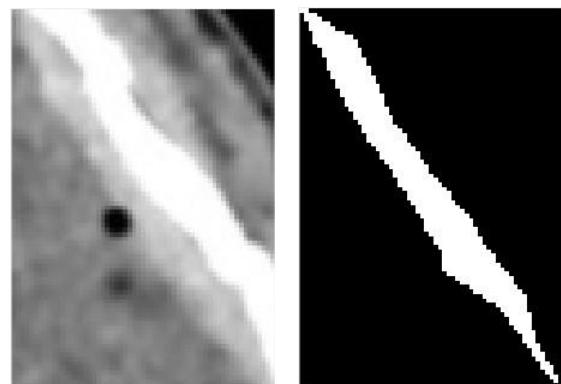


Gambar 2 Alur Labelling Pada Image Labeller

Gambar 2 merupakan alur *labelling* pada *image labeller*. Berikut ini penjelasan alur *labelling* dari blok diagram di atas:

1. Memasukkan citra file JPG yang akan di labeli.
2. Memilih ROI (Region of Interest) Label.
3. Memilih Labelling Rectangle pada ROI Label
4. Setelah di labeli maka dilakukan export label

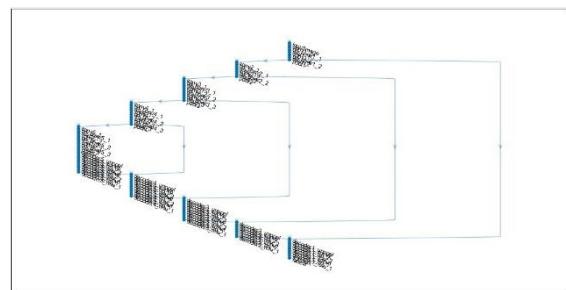
Pada tahap *crop image* dilakukan deteksi *Bounding Box* pada citra *Ground Truth* yang kemudian akan dilakukan *cropping* berdasarkan koordinat *Bounding box* pada citra asli dan citra *Ground Truth* seperti pada Gambar 3.



Gambar 3 Hasil *Crop* Berdasarkan *Bounding box* Pada Citra Asli dan Citra *Ground Truth*

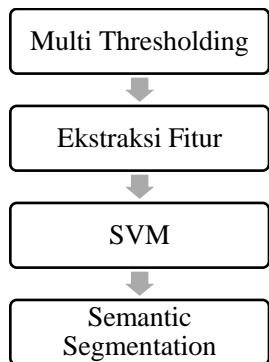
2.1.3 Layer Arsitektur VGG16 Pada SegNet

Layer VGG16 pada SegNet berupa *encoder-decoder* seperti pada Gambar 4. Komposisi dari layer segnet atau semantic segmentation memiliki 91 layer yang terdiri atas *input layer*, *convolution*, normalization, ReLU, *max pooling*, *softmax*, dan *classification layer*.



Gambar 4 Layer Encoder-Decoder SegNet VGG16

2.1.4 Tahapan Segmentasi



Gambar 5 Alur Tahapan Segmentasi

Gambar 5 merupakan alur *tahapan segmentasi*. Berikut ini penjelasan alur *tahapan segmentasi* dari blok diagram di atas:

1. Tahapan multi *thresholding* dilakukan untuk mencari area yang kemungkinan dianggap sebagai lesi.
2. Tahap selanjutnya dilakukan ekstraksi fitur pada label Ground Truth dan label deteksi Ground Truth yang akan digunakan untuk SVM.
3. Tahap selanjutnya dilakukan deteksi dengan svm dari feature yang telah di ekstraksi.
4. Tahap selanjutnya dilakukan semantic segmentation segnet.

2.1.5 Metode Evaluasi Segmentasi

Pada penelitian ini segmentasi dievaluasi dengan *metric precision*, true positive rate, true negative rate, dice similarity. Precision yaitu mengukur ketepatan, true positive ratio yaitu mengukur sensitivitas, true negative ration yaitu mengukur kekhususan dan dice similarity yaitu mengukur tumpang tindih antara dua wilayah [5].

Persamaan 1 *Precision*

$$P = \frac{|O_{SR}^M \cap O_{GT}|}{|O_{SR}^M \cup O_{GT}|} \quad (1)$$

Dengan :

O_{SR}^M = Hasil segmentasi dari sebuah metode M

O_{GT} = Citra ground truth dari segmentasi manual

Persamaan True Positive Ratio

$$TP = \frac{|O_{SR}^M \cap O_{GT}|}{|O_{GT}|} \quad (2)$$

Dengan :

O_{SR}^M = Hasil segmentasi dari sebuah metode M

O_{GT} = Citra ground truth dari segmentasi manual

Persamaan True Negative Ratio

$$TN = \frac{|O_{SR}^M \cup O_{GT}|}{|O_{GT}|} \quad (3)$$

Dengan :

O_{SR}^M = Hasil segmentasi dari sebuah metode M

O_{GT} = Citra ground truth dari segmentasi manual

Persamaan Dice Similarity

$$D = \frac{2|O_{SR}^M \cap O_{GT}|}{|O_{GT}| + |O_{SR}^M|} \quad (4)$$

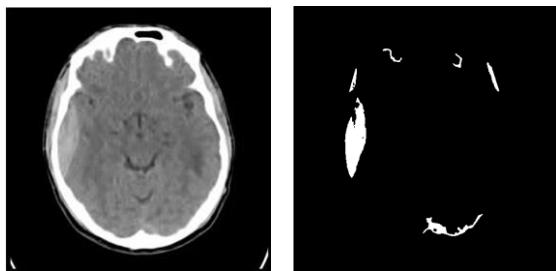
Dengan :

O_{SR}^M = Hasil segmentasi dari sebuah metode M

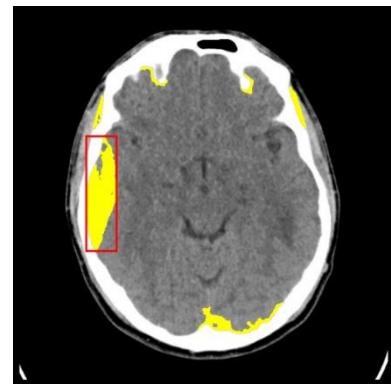
O_{GT} = Citra ground truth dari segmentasi manual

3 HASIL DAN PEMBAHASAN

Tahapan multi *thresholding* dilakukan untuk mencari area yang kemungkinan dianggap sebagai lesi, tahapan yang dilakukan mulai dari citra asli sampai menjadi citra BW hasil multithresh. Selama *processing* dilakukan metode seperti *quantization*, *convex hull*, *bwareaopen*, *erode*, dan *dilate*.



Gambar 6 Citra Asli (Kiri) Citra BW Hasil Multithresh (Kanan)



Gambar 8 Hasil Deteksi Area Menggunakan SVM

Tahap selanjutnya dilakukan ekstraksi fitur pada label *Ground Truth* dan label deteksi *Ground Truth* yang akan digunakan untuk SVM. Tahap ekstraksi fitur dilakukan dengan mengambil fitur *Area*, *Solidity*, *Orientation*, *Eccentricity*, *Extent* serta *Circularity*.

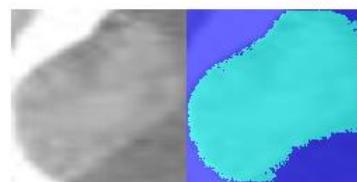
Ekstraksi fitur digunakan sebagai inputan SVM. Tujuan SVM untuk mendapatkan lokasi area lesi. Hasil SVM mendapatkan akurasi sebesar 0,70 yang dapat dilihat pada Gambar 7. Hasil 70,6% didapatkan dari nilai TP (*True Positive*) ditambah dengan TN (*True Negative*). Pada *confusion matrix* tersebut *True Positive* bernilai 52.8%, *True Negative* bernilai 17.9%, *False Positive* bernilai 24,6% dan *False Negative* bernilai 4.8%.

Confusion Matrix			
		1	2
Output Class	1	133 52.8%	62 24.6%
	2	12 4.8%	45 17.9%
		91.7% 8.3%	42.1% 57.9%
		78.9% 21.1%	70.6% 29.4%
Target Class			

Gambar 7 Confusion Matrix SVM

Hasil dari SVM dapat mendeteksi area lokasi lesi seperti pada Gambar 8 dibawah ini.

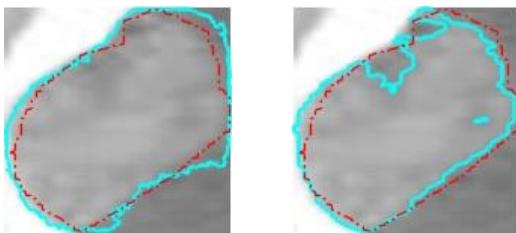
Hasil dari bounding box pada deteksi area lesi dilakukan cropping kemudian di gunakan untuk segmentasi menggunakan segnet. Hasil dari segmentasi menggunakan segnet dapat dilihat pada Gambar 9.



Gambar 9 Hasil Segmentasi Menggunakan SegNet

Pada pengujian segmentasi dengan menggunakan segnet terhadap 30 dataset mendapatkan hasil hitung akurasi rata-rata dengan nilai *precision* 0.70, dan *dice similarity* 0,52. Nilai *precision* terbesar 0.937 dan nilai *precision* terkecil 0.414 apabila mengabaikan nilai NaN, untuk *dice similarity*nya terbesar 0.908 dan nilai terkecil *dice similarity* sebesar 0.004.

Selanjutnya akan dilakukan perbandingan antara hasil segmentasi dengan thresholding dengan segmentasi segnet. Perbandingan dilakukan menghitung metrik hasil segmentasi terhadap ground truth asli.



Gambar 10 Kiri (SegNet) Kanan (Thresholding)

Garis berwarna merah merupakan area dari ground truth asli sedangkan garis berwarna biru merupakan hasil segmentasi.

Perbandingan dilakukan dengan membandingkan 30 dataset mendapatkan hasil perbandingan rata-rata *metric* antara segmentasi dengan segnet (*semantic segmentation*) dengan segmentasi *thresholding* dimana pada segnet rata-rata metrik *precision* sebesar 0,07760, *true negative rate* sebesar 0,6486, *true positive rate* sebesar 0,8027 dan *dice similarity* sebesar 0,6410, sedangkan pada *thresholding* rata-rata metrik *precision* sebesar 0,8890, *true negative rate* sebesar 0,8056, *true positive rate* sebesar 0,8841 dan *dice similarity* sebesar 0,8379. Berdasarkan data tersebut dapat dikatakan bahwa segmentasi menggunakan *thresholding* lebih baik.

4 SIMPULAN

Berdasarkan pada penelitian, pembuatan sistem hingga perbandingan menggunakan metode multilevel *thresholding* dan *semantic segmentation*, maka dapat ditarik kesimpulan berikut:

1. Sistem dapat digunakan dan berfungsi untuk mendeteksi lesi dan area lesi.
2. *Dataset* setelah *cropping* dan metode multi *thresholding* dengan SVM bisa mendeteksi lesi dan lokasi lesi.
3. Berdasarkan tabel hasil perbandingan rata-rata *metric* antara *semantic segmentation* dengan *thresholding* menghasilkan kesimpulan bahwa *thresholding* lebih baik.

5 DAFTAR PUSTAKA

- [1] W. Kuo, C. Häne, P. Mukherjee, J. Malik, and E. L. Yuh, "Expert-level detection of

acute intracranial hemorrhage on head computed tomography using deep learning," *Proc. Natl. Acad. Sci. U. S. A.*, vol. 116, no. 45, pp. 22737–22745, 2019, doi: 10.1073/pnas.1908021116.

- [2] A. S. Lundervold and A. Lundervold, "An overview of deep learning in medical imaging focusing on MRI," *Z. Med. Phys.*, vol. 29, no. 2, pp. 102–127, 2019, doi: 10.1016/j.zemedi.2018.11.002.
- [3] A. Clèrigues, S. Valverde, J. Bernal, J. Freixenet, A. Oliver, and X. Lladó, "Acute ischemic stroke lesion core segmentation in CT perfusion images using fully convolutional neural networks," *Comput. Biol. Med.*, vol. 115, p. 103487, 2019, doi: 10.1016/j.combiomed.2019.103487.
- [4] S. L. Liew *et al.*, "A large, open source dataset of stroke anatomical brain images and manual lesion segmentations," *bioRxiv*, pp. 1–11, 2017, doi: 10.1101/179614.
- [5] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Hybrid speckle noise reduction method for abdominal circumference segmentation of fetal ultrasound images," *Int. J. Electr. Comput. Eng.*, vol. 8, no. 3, pp. 1747–1757, 2018, doi: 10.11591/IJECE.V8I3.PP1747-1757.